

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

**Algoritmus pro automatickou obrazovou
detekci sítnicových lézí**

**The algorithm for automatic detection of
retinal lesions**

2015

Kovářová Veronika

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání bakalářské práce

Student: **Veronika Kovářová**
Studijní program: **B2649 Elektrotechnika**
Studijní obor: **3901R039 Biomedicínský technik**
Téma: **Algoritmus pro automatickou obrazovou detekci sítnicových lézí**
The Algorithm for Automatic Detection of Retinal Lesions
Jazyk vypracování: **čeština**

Zásady pro vypracování:

1. Nastudování problematiky screeningu a diagnostiky retinopatie nedonošených dětí.
2. Rešerše problematiky obrazové detekce sítnicových lézí a extrakce jejich geometrických parametrů.
3. Teoretický návrh algoritmu pro automatizovaný výpočet vzdálenosti sítnicových lézí od terče zrakového nervu.
4. Návrh a realizace segmentačního algoritmu pro detekci sítnicových lézí a extrakci geometrických parametrů ve vztahu k terči zrakového nervu.
5. Testování algoritmu na reálných patientských datech.
6. Vytvoření graficko-uživatelského rozhraní pro detekci sítnicových lézí.
7. Zhodnocení dosažených výsledků práce.

Seznam doporučené odborné literatury:

- [1] LEIS, John. *Digital signal processing using MATLAB for students and researchers*. Hoboken: Wiley, c2011, xii, 382 s. ISBN 978-0-470-88091-3.
- [2] SURI, Jasjit S, David L WILSON a Swamy LAXMINARAYAN.(eds.) *Handbook of biomedical image analysis: Volume 3: Registration Models*. New York: Kluwer Academic/Plenum Publishers, c2005, xvi, 574 s., [8] s. obr. příl. ISBN 0-306-48607-5.
- [3] SURI, Jasjit S, David L WILSON a Swamy LAXMINARAYAN. (eds.) *Handbook of biomedical image analysis: Volume I Part A Segmentation Models*. New York: Kluwer Academic/Plenum Publishers, c2005, xviii, 648 s., [8] s. obr. příl. ISBN 0-306-48550-81.
- [4] SURI, Jasjit S, David L WILSON a Swamy LAXMINARAYAN. *Handbook of biomedical image analysis: Volume II Part B Segmentation Models*. New York: Kluwer Academic/Plenum Publishers, c2005, xxii, 816 s., [8] s. obr. příl. ISBN 0-306-48605-92.
- [5] DOUGHERTY, Geoff. *Digital Image Processing for Medical Applications*. Cambridge: Cambridge University Press, 2009. ISBN-10: 0521860857.

Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí bakalářské práce: **Ing. Jan Kubiček**

Datum zadání: 01.09.2015

Datum odevzdání: 29.04.2016



doc. Ing. Jiří Koziolek, Ph.D.
vedoucí katedry

prof. RNDr. Václav Snášel, CSc.
děkan fakulty

Prohlášení a poděkování studenta

Prohlašuji, že jsem tuto bakalářskou práci na téma algoritmus pro automatickou obrazovou detekci sítnicových lézí vypracovala samostatně. Uvedla jsem všechny literární prameny a publikace, ze kterých jsem čerpala.

Ráda bych touto cestou poděkovala vedoucímu bakalářské práce za odborné vedení, cenné rady a připomínky během tvorby této práce a panu MUDr. Juraji Timkovičovi za spolupráci při tvorbě této práce.

Dne: 29.4.2016

Podpis: Kosařová

Abstrakt

Cílem této bakalářské práce je vytvoření automatického algoritmu pro obrazovou detekci sítnicových lézí, následné zkoumání jejich geometrických vlastností a vztahu velikosti vůči velikosti optického disku. Tento algoritmus je vyvíjen pro snadnější klasifikaci retinopatie nedonošených. Hlavní myšlenkou je detekce sítnicových lézí a jejich oddělení od pozadí. Algoritmus je prostředkován základními metodami zpracování obrazu a realizován v prostředí MATLAB. Součástí práce je také vytvoření příjemného graficko-uživatelského rozhraní pro snadnou práci s algoritmem.

Testování algoritmu proběhlo na reálných medicínských datech. Data nám byla poskytnuta Fakultní nemocnicí Ostrava.

Klíčová slova

Detekce, retinopatie nedonošených, sítnice, sítnicové léze, zpracování obrazu, RetCam 3, MATLAB.

Abstract

The aim of this bachelor thesis is to create an automatic algorithm for visual detection of retinal lesions and consequently scrutinising their geometric properties and relations between size and size of optical disc. This algorithm is being designed for easier classification of rethinopathy of prematurity. The main idea is to detect retinal lesions and their detachment from the background. The algorithm follows basic methods of image processing in the MATLAB enviroment. Constituent part of this thesis is also to design a user friendly graphical interface for easy use of the algorithm.

Testing of the algorithm has been approved on real medical data. The data were provided by Fakultní nemocnice Ostrava.

Key words

Detection, retinopathy of prematurity, retina, retinal lesions, image processing, RetCam 3, MATLAB.

Obsah

Seznam použitých symbolů a zkratk	8
1 Úvod	9
2 Anatomie oka	10
2.1 Stavba oka	10
2.2 Stavba sítnice.....	11
2.2.1 Cévní zásobení sítnice	11
3 retinopatie nedonošených	12
3.1 Formy retinopatie	12
3.2 Stádia retinopatie.....	12
3.3 Screening a léčba.....	13
3.3.1 Zóny retinopatie.....	13
3.3.2 RetCam3	13
3.3.3 Nepřímá Ofthalmoskopie.....	15
3.3.4 Léčba	15
4 Rešerše problematiky detekce sítnicových lézí.....	17
4.1 Metoda ověření přítomnosti lézí statickou kvalifikací	17
4.2 Detekce lézí užitím morfologické techniky rozdělování kandidátů	21
4.3 Detekce lézí metodou recursive region growing segmentation.....	24
4.4 Detekce lézí užitím matematické morfologické operace a pixelové kvalifikace ..	28
4.5 Detekce lézí metodou adaptivního prahování	31
4.6 Detekce lézí pomocí dvou fází detekování kandidátních lézí	33
5 Analýza patientských dat.....	37
6 Teoretický návrh algoritmu	38
6.1 Předzpracování snímku	38
6.1.1 Výběr vhodné chrominační složky retinálních záznamů	39
6.1.2 Ostření obrazu.....	40
6.1.3 Ekvalizace histogramu.....	41
6.1.4 Jasové transformace.....	42
6.1.5 Výběr zájmové oblasti (RoI)	43
6.2 Segmentace obrazu.....	43

6.2.1	Binarizace snímku	43
6.3	Extrakce geometrických parametrů.....	44
7	Graficko-uživatelské rozhraní	46
8	Testování algoritmu na reálných patientských datech.....	50
8.1	Výsledky testování	56
	Závěr.....	58
	Seznam použité literatury	59
	Seznam příloh.....	61

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

a. – artérie

lat. – latinsky

OD – optický disk

RoI – oblast zájmu (region of interest)

ROP – retinopatie nedonošených

tzv. – takzvaný

1 ÚVOD

Retinopatie nedonošených je onemocněním předčasně narozených dětí a je nejčastější příčinou dětské slepoty. Součástí screeningu a přesné diagnostiky onemocnění dětskou retinopatií je kvalitní zpracování obrazových záznamů dětské sítnice. Navržením a realizací funkčního algoritmu pro detekci retinálních lézí a extrakci jejich geometrických parametrů, usnadníme práci oftalmologům, zjednodušíme a zkvalitníme diagnostiku nemoci, která je nejvýznamnějším faktorem pro zabránění oslepnutí novorozence.

Cílem této bakalářské práce je vytvoření algoritmu pro detekování retinálních lézí a extrakci jejich geometrických parametrů. Obsahem této práce není pouze prezentování navrženého algoritmu, ale také seznámení s onemocněním retinopatií nedonošených, a také s principy použitých metod pro vývoj algoritmu. Tyto oblasti jsou nezbytné pro pochopení k čemu algoritmus slouží a jak pracuje.

První teoretická část bakalářské práce je zaměřená na přiblížení onemocnění retinopatií nedonošených. Tato část zahrnuje anatomický popis oka pro pochopení následujících kapitol, které jsou věnovány projevům dětské retinopatie, jejich formám, stádiím, a screeningu onemocnění.

Do teoretické části je také zahrnuta rešerše současné problematiky detekce retinálních lézí. Zde jsou shrnuty již existující techniky detekce retinálních lézí. Z důvodu nulového počtu technik detekce retinálních lézí u dětské retinopatie se veškeré zahrnuté techniky týkají diabetické retinopatie.

V praktické části je rozebrán návrh a realizace algoritmu pro detekci retinálních lézí a extrakci jejich geometrických parametrů, jednotlivé použité metody zpracování obrazu a segmentace a jejich principy. Součástí je také postup tvorby graficko-uživatelského rozhraní pro detekci retinálních lézí a extrakci jejich geometrických parametrů

2 ANATOMIE OKA

2.1 Stavba oka


Oko (lat. bullbus oculi) je jedním ze smyslových orgánů. Tento, na světlo reagující, párový orgán zprostředkovává člověku vidění. Struktura oka je plně přizpůsobená potřebě zaostření paprsku světla dopadajícího na sítnici. Oční bulbus, uložený v obličejové části lebky, má tvar mírně asymetrické koule, o průměru zhruba 25 mm, jehož stěna je tvořena třemi vrstvami.

Povrch bulbu pokrývá bělma (sclera), která postupně přechází v přední průhlednou část zvanou rohovka (cornea). Bělma je tuhou, bílou, vazivovou částí, ke které se upínají okohybné svaly. Rohovka je průhledný útvar v předním segmentu bulbu. Má kopulovité zakřivení a optickou mohutnost 40 dioptrií. Výrazně se podílí na správném lomu světla při průchodu okem.

Druhou vrstvou je, na cévy bohatá živnatka (uvea), často také nazývaná cévnatka. Zde se soustřeďuje velké množství cév a pigmentových buněk. V přední části přechází v řasnaté tělísko (corpus ciliare), které umožňuje pomocí svalů akomodaci oka. Řasnaté tělísko je složeno z hladké svaloviny a na povrchu je opatřeno výběžky, na kterých je zavěšená čočka. Ke střední vrstvě se také řadí duhovka (iris). Duhovka má kruhovitý tvar a je utvořena z hladké svaloviny, která umožňuje rozšiřování nebo zužování zornice (pupila), čímž reguluje množství procházejícího světla do oka. Zbarvení duhovky je určováno množstvím pigmentových buněk zde obsažených. Za duhovkou je umístěná čočka (lens). Průhledná, bikonvexní část oka má funkci společně s rohovkou lámat paprsky, aby co nejpřesněji dopadaly na sítnici. Optická mohutnost čočky je okolo 15 dioptrií.

Výplň bulbu zajišťují dvě rozdílné tekutiny. Mezi čočkou a rohovkou se nachází tzv. komorová voda. Tato hustá tělní tekutina obsahuje 99 % vody. Komorová voda udržuje nitrooční tlak a vyživuje okolní tkáň. Vnitřní část oka vyplňuje sklivec (corpus vitreum). Je to průhledné rosolovité těleso, které z 98 % tvoří voda. Zbýlými prvky sklivce jsou chlorid sodný, bílkoviny a kyselina hyaluronová, která na sebe váže vodu, a vytváří tím rosolovitost sklivce.

Poslední vrstvou očního bulbu je sítnice (retina). [1][2]



Obrázek 1: Stavba oka [14]

2.2 Stavba sítnice

Sítnice je nejvnitřnější vrstvou očního bulbu. Tato blána je tvořena několika vrstvami a je 0,2 – 0,4 mm silná. Snímá a předzpracovává světelné signály, které přichází na sítnici skrze čočku. Retina je především tvořena zrakovými buňkami – tyčinkami a čípkami.


Tyčinky jsou tzv. fotoreceptory. Na sítnici je jich okolo 120 miliónů. Jsou to přeměněné neurony, které díky proteinu rodopsinu, jenž je schopný se rozkládat po dopadu fotonu, zapříčiňuje vznik elektrického impulsu. Tyčinky nejsou schopné rozlišovat barvy, rozlišují pouze odstíny šedi, ale mají lepší citlivost na světlo, díky čemu umožňují černobílé vidění za šera.

Čípky, kterých je okolo 6-7 miliónů, vnímají především barvy. Svou slabší citlivostí na světlo způsobují ztrátu schopnosti barevného vidění za šera. Známe tři funkční typy čípků, rozlišené podle vnímání určité barvy, tedy červené, zelené a modré. Čípky obsahují oční pigmenty jodopsiny (též fotopsiny), které jsou specializovány pro jednotlivé barvy.

Na sítnici se dále nachází žlutá skvrna (macula lutea). Průměr žluté skvrny je okolo 5 mm. Toto místo dominuje největším množstvím čípků, čímž má schopnost zajistit nejostřejší vidění. Tyčinky žlutá skvrna neobsahuje vůbec.

Slepá skvrna je oblastí, kde se nevyskytují tyčinky ani čípky. Nachází se v místě výstupu zrakového nervu ze sítnice.

Místo, kde se sbíhají nervy sítnice do očního nervu, je pojmenováno optický disk. Z této oblasti vybíhají jemné žíly a tepénky sítnice. [1][2]



Obrázek 2: Stavba sítnice [13]

2.2.1 Cévní zásobení sítnice

Hlavní zásobovací tepnou sítnice je arteria ophthalmica. Ta vstupuje do očníce skrze canalis opticus a následně se dělí. Dále je zde a. centralis retinae, která vstupuje do nervus opticus, a spolu s ním postupuje až k papilla nervi optici, kde se dále dělí na dolní a horní větev, které se rozdělí temporálně a nasálně. Temporální větev zásobuje žlutou skvrnu. Veškeré vrstvy sítnice jsou zásobeny a. centralis retinae až na tyčinky a čípky, které zásobují kapiláry cévnatky.

Žilní krev ze sítnice odtéká horní a dolní vénou ophthalmica. [1][2]

3 RETINOPATIE NEDONOŠENÝCH

Retinopatie nedonošených, dále jen ROP, je vazoproliferativní onemocnění, které postihuje předčasně narozené a nezralé děti, které se narodily před 32. gestačním týdnem, a u nichž porodní hmotnost nedosahuje 1500 g. Vzhledem k tomu, že tyto děti trpí respirační nedostatečností, podstupují oxygenoterapii, kde nadměrná koncentrace kyslíku je nejvýznamnějším faktorem vzniku tohoto onemocnění. Retinopatie nedonošených je nejčastější příčinou dětské slepoty. Téměř 70 % nevidomých dětí tvoří pacienti, kteří prodělali ROP. [3]


3.1 Formy retinopatie

ROP probíhá ve dvou formách. Akutní ROP a chronická ROP. Akutní forma se vyznačuje porušením tvorby cév nezralé sítnice. Chronický pozdní vývoj je charakteristický tvorbou retinovitrealních fibrovaskulárních membrán, které svým tahem mohou zapříčinit úplné nebo parciální odchlípení sítnice. [1][3]

3.2 Stádia retinopatie

Retinopatie nedonošených se projevuje 5 vývojovými stádii.

- Stádium 1 - Prvnímu stádiu je charakteristická tzv. demarkační linie, která odděluje vaskularizovanou oblast od avaskularizované oblasti sítnice.
- Stádium 2 - Ve druhém stádiu se demarkační linie rozšiřuje a nabývá hřebenovitého tvaru. Objevují se ojedinělé oblasti s kapilární proliferací a neovaskularizací.
- Stádium 3 - Třetí stádium představuje hřeben s extraretinální fibrovaskulární proliferací do sklivce.
- Stádium 4 - Ve čtvrtém stádiu dochází k částečnému odchlípení sítnice. Toto částečné odchlípení sítnice může proběhnout buď bez poškození části sítnice s makulou, nebo s poškozením makuly.
- Stádium 5 - Totální odchlípení sítnice je projevem posledního, pátého stádia. [3][4]




Obrázek 3: Jednotlivá stádia retinopatie nedonošených [15]

3.3 Screening a léčba

Cílem screeningu je včasné odhalení před-prahových forem a především včasné odhalení III. prahové formy retinopatie, kdy je již nutná léčba nemoci. Běžně se vyšetřují děti narozené před 32. gestačním týdnem, a také děti, jejichž porodní váha nedosáhla na 1500 g. Vyšetření se provádí v intervalech jednoho až dvou týdnů do úplné vaskularizace III. zóny. První kontrola je indikována 5 týdnů po narození miminka. Sledování stavu sítnice je možné ukončit v 36. postkoncepčním týdnu, nebo po dokončení úplné vaskularizace sítnice, u které nedošlo ke vzniku retinopatie. Dříve se prováděly kontroly pomocí nepřímého oftalmoskopu, dnes se využívá pokroku v medicíně, a to vyšetření retinální kamerou RetCam3. [1][3][5]

3.3.1 Zóny retinopatie

U screeningu se při diagnostice využívá lokalizace změn na očním pozadí podle jednotlivých zón. Zóna I. je velmi malá, ale je nejvíce riziková, protože nemoc může velice rychle dosáhnout 3. stádia, proto je nutné časté sledování stavu sítnice. ROP počínající v zóně III má dobrou prognózu, že nedosáhne vyšších stádií. Zóna III. je nejčastěji postižena retinopatií. [1][3]



Obrázek 4: Jednotlivé zóny, podle kterých se diagnostikuje ROP [15]

3.3.2 RetCam3

Je širokoúhlý zobrazovací systém, který umožňuje podrobně sledovat a zaznamenávat vývoj očního pozadí. Přístroj byl vyvinut firmou Clarity Medical System, která se specializuje na retinální kamery. Kamera umožňuje jak pořízení kvalitního širokoúhlého záběru sítnice, tak i pořízení videozáznamu, a jejich uchování v digitální formě a srovnávání snímku v čase. Obraz pořízený přístrojem je reálný a nepřevrácený, čímž eliminuje riziko subjektivní chyby vyšetřujícího, oproti práci s nepřímým oftalmoskopem. Obraz je také zvětšený.

Mezi velké výhody patří výměnné čočky kamery, kdy je možné pořídit záznamy sítnice v širokoúhlém záběru až 130 °. To umožňuje detailněji zaznamenat i nejvzdálenější místa sítnice. U novorozenců bývá běžně používána čočka s úhlem 120 °. Ostatní čočky s menšími úhly záběru mají lepší kontrastní vlastnosti a také možnost většího přiblížení a detailnějšího prozkoumání sítnice. Dále je velkým přínosem možnost snímat sítnici již dvoutýdenních novorozenců. [6]



Obrázek 5: Přístroj RetCam3 [20]

Tabulka 1: Technické parametry přístroje RetCam3

Parametry počítače

Operační systém	Windows 7
Procesor	Pentium Dual Core 2,4 GHz
Připojení	LAN/Multi USB
HDD	1 TB
Systémová paměť	4 GB

Tabulka 2: Ostatní parametry integrovaného mobilního vozíku

Další parametry přístroje

Monitor	21" x 23"
Pracovní deska	41"
Pracovní plocha	230 čtverný inch
Zobrazení monitoru	23"
Napájení	Napájecí kabel, baterie
Tiskárna	Kombinovaná klasická s fototiskárnou
Baterie	Záložní baterie, provoz 15 min.
Ostatní	4 uzamykatelné zásuvky, fluorescenční modul pro angiografii

3.3.3 Nepřímá Ofthalmoskopie

Jedna z metod vyšetření dětí je nepřímá oftalmoskopie. Tato metoda vyšetření očního pozadí využívá upraveného zdroje světla a čočku s optickou mohutností 20-30 dioptrií, která se klade do blízkosti vyšetřovaného oka. Nepřímý oftalmoskop si lékař umístí na hlavu. V této části zařízení je situován zdroj světla. Tímto způsobem lze rychle diagnostikovat mnoho patologických stavů jako je odchlípnutí sítnice nebo krvácení do sklivce. Obraz očního pozadí a sklivcové dutiny je obrácen, rozsah pozorovatelné oblasti je pouze 45 °.



Obrázek 6: Nepřímý oftalmoskop[19]

3.3.4 Léčba

U retinopatie nedonošených dochází v 60–80 % ke spontánnímu vyléčení onemocnění bez jakéhokoliv zásahu a bez funkčních následků. 10–30 % dětí je ohroženo dalším rozšířením nemoci. Cílem léčby je ošetřit bezcévní periferní části sítnice. K tomuto se využívá buďto kryoterapie, nebo léčba pomocí fotokoagulace diodovým laserem. Tyto metody mají za cíl destrukci periferní avaskularizované části sítnice, a tím zachránit centrální část sítnice, kde jsou důležité složky vidění.

Při kryoterapii dochází ke zmražení tkáně velmi nízkými teplotami. Abláční kryosonda dosahuje teplot $-60\text{ }^{\circ}\text{C}$ až $-80\text{ }^{\circ}\text{C}$. Ošetřuje se avaskulární část sítnice vytvářením jednotlivých ložisek, která se postupně spojují v celek. Zásah sítnice lékař pozná zběláním místa zásahu pomocí nepřímé oftalmoskopie. Během zákroku dojde k promražení skléry, cévnatky, což je nežádoucí. U této bolestivé metody je vyžadována lokální nebo celková anestezie.

Druhou a také šetrnější metodou je fotokoagulace pomocí diodového laseru. Diodový laser zaručuje přesnější umístění bodů na sítnici a tím šetrněji likviduje tkáň teplem. Tento zákrok je přímo sledován retinální kamerou RetCam3, která zaručuje přesné umístění laserového bodu, a lékař ihned vidí místo zásahu laserem. Stejně jako u kryoterapie jsou na sítnici vidět bílé oblasti po užití laseru. Vzhledem k tomu, že bod světla laseru je menší než mrazicí bod u kryoterapie, je nutné při zákroku vytvořit více jednotlivých ložisek.

Obě metody dosahují zhruba stejných výsledků, ovšem metoda fotokoagulace je pro novorozence daleko šetrnější, i díky tomu, že u zákroku diodovým laserem stačí lokální anestezie, kdežto u kryoterapie je častěji vyžadována celková anestezie, která je pro novorozence daleko více riziková. Laserovou fotokoagulaci není možno použít, pokud je některé z optických prostředí oka zakaleno. [1][3]

4 REŠERŠE PROBLEMATIKY DETEKCE SÍTNICOVÝCH LÉZÍ

4.1 Metoda ověření přítomnosti lézí statickou kvalifikací

Dosavadní výzkumy prokázaly, že rysy jako jsou tvar, velikost, textura a orientace, nejsou dostačující pro jednoznačnou identifikaci sítnicových lézí. Na druhou stranu, barevná informace se prokázala jako velmi účinná pro detekci lézí za určitých podmínek. Pokud se barva pozadí na kvalitním snímku sítnice dostatečně sjednotí, aplikací správného prahu lze jednoduchým a účinným způsobem detekovat léze na sítnici. Ovšem nestejnorodé snímky o různé kvalitě vyžadují rozdílné prahové nastavení. Proto byla vyvinuta metoda statistické kvalifikace pro identifikaci lézí.

Objekty na snímku jsou popsány několika rysy $f_1, f_2, f_3, \dots, f_k$ jako jsou barva, velikost, tvar, textura a dalšími komplexními charakteristikami. Tyto rysy formují k -dimenzionální prostor F . Ideálně je potřeba najít takový prostor F , kde různé objekty mapují různé neprotínající se klastry (třídy) v tomto prostoru. Pokud je splněna tato podmínka, je možno jednoduše identifikovat různé objekty, a zařadit je do odpovídající třídy (klastru), podle určitých pravidel.

Předpokládá se, že máme N různých objektů nebo tříd k identifikaci na obrázku. Je zavedeno několik proměnných. $C(f_1, f_2, f_3, \dots, f_k)$ značí střed třídy i v k -dimenzionálním prostoru F , kde $i = 1, 2, \dots, N$. Neznámé objekty měření hodnot funkce v prostoru F se značí $X(x_1, x_2, \dots, x_k)$. Rozlišovací funkce se značí $D_i(X)$, kde $i = 1, 2, \dots, N$, a je použita pro klasifikaci, zda X náleží třídě i . Daný specifikovaný pixel x s hlavním vektorem X , klasifikujeme jako pixel x , patřící do třídy i , pokud $D_i(X)$ je maximum podél všech $D_j(X)$, kde $j = 1, 2, \dots, N$ a $j \neq i$.

Předtím, než je provedena statistická kvalifikace, je třeba vyřešit dvě otázky. První je výběr vhodného prvku prostoru tak, aby měly léze zřetelně odlišnou charakteristiku od jiných objektů a pozadí sítnice. Druhou záležitostí je odvození vhodné rozlišovací funkce $D(X)$, která třídí každý pixel na obrázku sítnice do tříd „léze“ nebo „ostatní“.

V počátku šetření se používá pouze rys barvy v prostoru F . Barevný snímek obsahuje tři chrominační složky (R-červená, G-zelená, B-modrá) a každá plocha má 256 úrovní intenzity. Barva může být také reprezentována symboly θ , Φ a L ve sférických souřadnicích.

Vztahy mezi jednotlivými barvami jsou definovány takto:

$$L = (R^2 + G^2 + B^2)^{1/2} \quad (1)$$

$$\theta = \text{Arctan}(G/R) \quad (2)$$

$$\varphi = \text{Arccos}(B/L) \quad (3)$$

kde L znamená expozici nebo jas obrázku, zatímco θ a Φ zdůrazňují rozdíly nebo změny barev. Je-li L konstantní, pak θ a Φ popisují barvu v isoiluminantním prostoru. Vzhledem k tomu, že zaměření tohoto algoritmu je rozlišování mezi nažloutlými lézemi a tmavými objekty na barevném snímku sítnice, byla zahrnuta expozice a jas, jako změny barevné informace. Z tohoto důvodu bylo

vybráno θ a Φ jako hlavní prostor $F(fl, f\theta, f\Phi)$. Dále je třeba odvodit odpovídající diskriminační funkci. Zde byla zvolena funkce $D(X)$ odvozena z Bayesova pravidla.

Zadní pravděpodobnost je označena $P(C_i/X)$. To značí pravděpodobnost měření vektoru X patřícího do třídy i . Pokud je $P(C_i/X)$ větší než $P(C_j/X)$, kde $j = 1, 2, \dots, N$ a $j \neq i$, pak by mělo být závěrem, že X náleží třídě i . Na základě Baysovy teorie, $P(C_i/X)$ může být vyjádřeno jako:

$$P(C_i/X) = P(C_i)P(x/C_i)/P(X) \quad (4)$$

Zde $P(C_i)$ je prioritní pravděpodobnosti třídy i na obrázku ke klasifikaci. $P(x/C_i)$ je podmíněná pravděpodobnost X dané třídy i . Jinými slovy, rozlišující funkce může být definována jako zadní pravděpodobnost:

$$D_i(X) = P(C_i/X) = P(C_i)P(X/C_i)/P(X) \quad (5)$$

Vzhledem k tomu, že $P(X)$ je nezávislé na jakékoliv třídě, neovlivní výběrovou sílu $D_i(x)$, takže může být bezpečně ignorováno. Pak je rozumné, aby se $P(X/C_i)$ blížilo normálnímu rozložení pravděpodobnosti.

$$P(C_i/X) = \frac{1}{|\Sigma_i|^{1/2} \sqrt{2\pi}} \exp \left[-\frac{(X-C_i)^T \Sigma_i^{-1} (X-C_i)}{2} \right] \quad (6)$$

Nakonec se předpokládá, že kovariační matice:

$$D_i(X) = -(X - C_i)^T (X - C_i) \quad (7)$$

Σ_i ($i=1, 2, \dots, N$) z předchozí rovnice je identifikací pro všechny třídy a $P(C_i)$ je pravděpodobně téměř stejné pro $i = 1, 2, \dots, N$. Použitím logaritmického operátoru ze vzorce č. 2, získáme následující. Ignorujeme záporné znaménko ve vzorci č. 4 a získáme vzorec č. 5, který se nazývá *minimum distance diskriminant* (MDD) minimální diskriminační vzdálenost.

$$D_i(X) = (X - C_i)^T (X - C_i) \quad (8)$$

Použitím $D_i(X)$ definovaného v rovnici (8) u problému detekce přítomnosti lézí na obrazech sítnice, nyní nadefinujeme pouze 2 třídy – nažloutlé místa (léze) a tmavší červené pozadí. Pro každý pixel $X(x_L, x_\theta, x_\Phi)$ na retinálním snímku, jsou vypočítány diskriminanty $D_{lesion}(x)$ a $D_{bkgnd}(X)$. Pokud hodnota $D_{lesion}(x)$ je nižší než $D_{bkgnd}(X)$, pak je pixel X klasifikován jako léze, jinak je klasifikován jako pozadí. Tímto způsobem se rychle detekují sítnicové léze.

Součástí tohoto algoritmu je také úprava jasu snímku. Ta se provádí z důvodu nestejnorodosti osvětlení různými příčinami. Tato úprava je provedená pomocí jasové transformace $y = \beta * x^\alpha$, kde x je hodnota pixelu originálního vstupního obrazu, y je hodnota pixelu po nastavení jasu a $0 \leq \alpha \leq 1$, $\beta = inmax^{1-\alpha}$. $Inmax$ je hodnota horní meze intenzity jasu ze vstupního obrázku, požadovaná v transformační funkci $0 \leq inmax \leq 225$. Aplikováním tohoto nastavení je algoritmus schopen detekovat léze, nacházejících se v tmavších částech snímku.

Posledním krokem je ověření přítomnosti léze. Znamená to minimalizování chybného označení nepravých lézí a zachování pouze pravých lézí. Zde se využívá znalostí, ze kterých vyplývá,

že léze mívá zřetelný okraj. Porovnáváním malých lokálních sousedních pixelů, je tato metoda schopna určit, zda je světlý bod léze, nebo ne. V obrazech, které obsahují léze, bývá velký kontrast mezi místy výskytu léze a pozadím. Na základě těchto vlastností, je proveden druhý přechod přes snímek pomocí místního okna $M \times M$ pro rozlišení, zda se v rámci tohoto okna vyskytují pravdivé léze. Prvně je uplatněn počáteční vyhlazovací krok, tj. pořízení $N \times N$ místního průměru, ke snížení a potlačení rušení šumem rozptýlených bodů na originálním snímku. Následně je původní snímek sítě procházen pixel po pixelu. Pro každý pixel x , který byl klasifikován jako léze, je definováno $W^m(x)$ lokální $M \times M$ okno se středem v x . V každém lokálním okně $W^m(x)$ je g_{max1} a g_{min1} označující nejvyšší a nejnižší hodnotu barvy v $W^m(x)$. D_{maxmin} je rozdíl mezi g_{max1} a g_{min1} . k_{max} a k_{min} jsou váhy g_{max1} a g_{min1} , respektive g_{max2} a g_{min2} jsou váhy maxima a minima $W^m(x)$.

$$g_{max2} = g_{max1} - \frac{D_{maxmin}}{2} * k_{max} \quad (9)$$

$$g_{min2} = g_{min1} - \frac{D_{maxmin}}{2} * k_{min} \quad (10)$$


Průměrné maximum a minimum $W^m(x)$ jsou vyjádřeny jako

$$\bar{g}_{min} = \frac{1}{\sum_{g=g_{min1}}^{g_{min2}} x_g} * \sum_{g=g_{min1}}^{g_{min2}} g \quad (11)$$

$$\bar{g}_{max} = \frac{1}{\sum_{g=g_{max1}}^{g_{max2}} x_g} * \sum_{g=g_{max1}}^{g_{max2}} g \quad (12)$$

Můžeme definovat lokální míru D následovně: $D = \bar{g}_{max} - \bar{g}_{min}$


1. Pokud je D větší než daný práh D_T , znamená to, že je zde velká pravděpodobnost, že mají dva kontrastní objekty v rámci tohoto lokálního okna. Proto, pro každé $W^m(x)$ jehož $D \geq D_T$, jestliže pixel C připadá na rozsah jasu $[g_{max2}, g_{min2}]$ v originálním vyhlazeném snímku sítě, zůstane klasifikovaný jako léze, jinak jsou klasifikovány jako pozadí.
2. Pokud je D menší než D_T v $W^m(x)$, může to znamenat jednu z následujících situací:
 - a) $W^m(x)$ může spadat na vnitřní oblast pozadí v případě, že pixel x by měl náležet pozadí, ale je špatně klasifikován jako bod léze klasifikátorem. Založený na daném kritériu D , x bude reklasifikován jako pozadí.
 - b) $W^m(x)$ může kompletně spadat pod lézi, v takovémto případě některé pravdivé body léze v takovém okně mohou být rekonfigurovány jako pozadí. Nicméně toto neovlivní naše výsledky, protože zaměření je na detekci přítomnosti lézí, a ne nepřesné tvary a velikosti lézí. [7]



Obrázek 7: Výsledné detekované světlé léze

4.2 Detekce lézí užitím morfologické techniky rozdělování kandidátů


První částí je předzpracování snímku. To zahrnuje redukci rozdílu v osvětlení stínovou korekcí a zvýšení kontrastu mezi prvky sítnice a pozadím. Těmto nastavením předchází upravení velikosti obrázku na standardní velikost 640x860 pixelů, což je důležité pro možnost použití snímku z více různých databází. Metoda využívá zelenou chrominační vrstvu obrázku. Na zelené chrominační vrstvě snímku se zobrazí prvky sítnice v nejlepším kontrastu.



Obrázek 8: Obrázek (vlevo) znázorňuje sítnicový snímek se separovaným zeleným kanálem, snímek (vpravo) je již po před-přípravě.

Samotná detekce léze probíhá prvotním výběrem objektů, které mají podobnou charakteristiku jako léze, a jsou označeny jako kandidáti za použití morfologické techniky, která se nazývá kandidátní segmentace. Klíčovou myšlenkou této metody je rozdílný profil červených lézí od profilu ostatních červených oblastí, jako jsou cévnatky na sítnici. Červené léze se oddělí od pozadí pomocí operace tzv. *flood-fill*, provedené na pixelech pozadí předzpracovaného snímku. Následuje odečtení předzpracovaného obrazu od obrazu, na kterém byla provedena *flood-fill* operace.

Druhou částí je převedení obrázku na binární formu s prahem α_I , který je počítán ze střední intenzity z předzpracovaného snímku (m_{prd}). Experimentálně byla stanovena hodnota prahu jako: $12 \times m_{prd}$. Toto je nejvhodnější pro porovnávání mezi pozitivními a falešně pozitivními (FPs) lézemi.



Obrázek 9: Snímek (vlevo) znázorňuje morfologické operace na předzpracovaném snímku, (pravý) snímek je po binarizaci morfologické operace

Ačkoliv morfologické operace mají za výsledek vysoký stupeň rozlišení lineárních tvarů od kruhovitých, výsledný obrázek stále zahrnuje některé cévy a nepotřebné artefakty, jakými je

například fovea, která má velmi podobné rysy jako červené léze. Tyto artefakty (znázornění cév, optického disku a fovey) nejsou potřebné při detekci lézí a jsou tedy odečteny ze snímku k získání nového snímku obsahujícího červené léze a jen málo nepravých objektů.




Obrázek 10: Snímek po redukci artefaktů

Snímek po kandidátní segmentaci může stále zahrnovat falešné léze. Proto byla vypočtena sada 9 rysů pro každého kandidáta. Jsou zvolené rysy G a P zastupující zelený kanál a předzpracovaný snímek.

- I. Poměr stran $r = l/w$, kde l je délka nejdelší osy kandidáta a w je šířka kandidáta na ose kolmé k ose délky.
- II. Plocha $a = \sum_{j \in X} 1$, kde x je sada pixelů kandidáta.
- III. Perimetr $p = n_0\sqrt{2} + n_0$, kde n_0 je číslo každého sudého a lichého řetězce kódů.
- IV. Kruhovitost $c = 4\pi a/p^2$. Udává míru kruhovitosti a pravidelnost kandidáta
- V. Excentricita e je poměr vzdálenosti mezi ohniskem elipsy a její hlavní osou šířky. Tyto hodnoty jsou mezi 0 (pro kruh) a 1 (pro úsečku)
- VI. Průměrná síla kandidáta v G, $m_{grn} = i_{grn}/a$
- VII. Vnitřní směrodatná odchylka z G, δ_{grn}
- VIII. Průměrná síla kandidáta v P, $m_{prd} = i_{prd}/a$
- IX. Vnitřní směrodatná odchylka z P, δ_{prd}

Kde i_{grn} a i_{prd} znamenají celkovou intenzitu obrázku se zeleným kanálem a celkovou intenzitu předzpracovaného obrázku.

Dalším krokem je klasifikace, kde je cílem klasifikovat každého kandidáta, buď jako skutečnou červenou lézi nebo nepravou červenou lézi podle pravidel, které jsou vypsány výše.



Obrázek 11: Obrázek (vlevo) je po klasifikaci, obrázek (vpravo) znázorňuje léze po klasifikaci na originálním šedém snímku

Tato metoda dosahuje velmi dobrých výsledků. Ačkoliv výsledky této metody jsou velmi příznivé, je třeba vyvíjet další metody k většímu snížení počtu falešně pozitivních lézí. Velkým nedostatkem této metody je detekce léze, která se může nacházet v místě fovey. [8]

4.3 Detekce lézí metodou recursive region growing segmentation


U předzpracování dochází ke zvýšení kontrastu, protože u obrázků dochází ke zhoršení kontrastních vlastností směrem k okrajům snímku. Také může nastat zhoršení kontrastu a barevných vlastností u různých etnických menšin.



Obrázek 12: (Levý) snímek je před úpravou kontrastu, (pravý) snímek je po úpravě kontrastu


K identifikaci normálních struktur (optický disk, krevní cesty a fovea) se využívá kontrastních vlastností těchto struktur. Optický disk se identifikuje pomocí vlastnosti velké změny intenzity sousedních pixelů. Cévy byly identifikovány pomocí vícevrstvé perceptron neuronové sítě, jejíž vstupy byly odvozeny z principu analýzy složky obrázku a detekce hran z prvního principu složky.

Ještě před samotným rozpoznáním léze se standardizuje barva. Z důvodů rozdílných vlastností sítnic v odražení světla, může dojít k jiným zbarvením sítnicových snímků, u odlišných etnik.



Obrázek 13: Různorodost snímku podle etnik


Kvůli těmto problémům, se obrázky upravují, na červeno-oranžový standard.



Obrázek 14: Snímky po úpravě na červeno-oranžový standard

Exudáty jsou léze žluté barvy, charakteristické různými tvary, velikostí s ostrými okraji. Pro detekci těchto žlutých lézí se využívá algoritmus s názvem „recursive region growing segmentation“ (RRGS). Základem RRGS je identifikace podobných pixelů v určité oblasti pro určení polohy hranice. K zjištění, zda jsou dva sousední pixely podobné, musí splňovat několik kritérií, jako je zelený kanál nebo barva. V RRGS jsou sousední pixely ve stejné oblasti považovány za poměrně homogenní vlastnosti šedé stupnice. Každý pixel p , o souřadnicích (x, y) , má čtyři sousední pixely orientované nahore, dole, vpravo, vlevo o souřadnicích $(x, y+1)$, $(x, y-1)$, $(x+1, y)$, $(x-1, y)$ v daném pořadí. Přilehlé pixely p_i , kde i je horizontální nebo vertikální souřadnice vzhledem k p .

První krok RRGS algoritmu je výpočet rozdílu v intenzitě mezi p a p_i . Pokud je rozdíl menší než prahová hodnota 10, pak je p_i přidáno do této oblasti a je nastaveno na p . Tento proces pokračuje tak dlouho, dokud se veškeré pixely zvažované ke slučování a původní pixely nesloučí v oblast. Střední intenzita oblastí byla vypočtena a nahradila původní intenzitu sloučených pixelů. Cyklus se opakuje, dokud není celý snímek segmentován.




Obrázek 15: Snímek po aplikování algoritmu RRGS

Využitím prahování se vytvoří binární obraz. Střední intenzita pozadí, které je definováno jako oblast s nejvíce pixely, byla stanovena jako prahová hodnota pro klasifikaci snímku. Segmentované oblasti nad touto prahovou hodnotou byly nastaveny na intenzitu 255 (bílá) a klasifikovány jako exudátní oblasti, kdežto oblasti pod prahovou hodnotou byly nastaveny na intenzitu 0 (černá), a klasifikovány jako bez-exudátní oblasti. I přes to, že optický disk má velmi podobnou barvu jak exudáty, má dobře definovatelnou hranici. Z obrázku je extrahován pomocí algoritmu pro rozpoznání polohy.

Nakonec se exudáty zbarví do modrých regionů a jsou vyobrazeny na původním snímku.




Obrázek 16: Původní snímek s modře zbarvenými exudáty



Obrázek 17: Další příklad rozpoznání exudátů

Za tmavé léze jsou považovány mikroaneurysma a krvácení na sítnici. Mikroaneurysmata jsou malé, kulaté, červené tečky na sítnici, zatímco krvácení má uspořádání tečky, skvrny nebo plameny. Tyto léze mají velmi podobnou barvu jako pozadí a krevní cesty. Pro tyto léze je použitý zelený kanál, protože obsahuje více informací a kontrastu pro červené prvky. Pro zostření okrajů byl použit *Moat operator*.




Obrázek 18: (Vlevo) je normální obrázek, (vpravo) je výsledek po zaostřovací operaci

Dále se využívá pro detekci lézí RRGs, stejně jako u žlutých lézí. Krevní cesty ale v tomto případě jsou zařazeny do stejné skupiny jako léze. Pro předcházení tohoto problému se využívá technika neuronové sítě (NN), která identifikuje krevní cévy a extrahuje je ze snímku.



Obrázek 19: Identifikace a extrakce krevních cév




Obrázek 20: Výsledný obrázek po modrém zbarvení lézí

Při detekci žlutých lézí dosahuje daná metoda vysoké úrovně, pouze velmi malé léze nemusí být identifikovány. Detekce červených lézí je ovšem obtížnější. Je třeba zdokonalit přesnost detekce červených lézí v této metodě, protože stále dochází velmi často k jejich záměně s jinými segmenty, a krvácení blízko krevních cest nebylo detekováno vůbec.[9]

4.4 Detekce lézí užitím matematické morfologické operace a pixelové kvalifikace

V předzpracování snímku se využívá informace intenzity z červeného i zeleného kanálu stejného sítnicového obrázku. Toto nastává z důvodu výhod jednotlivých barevných kanálů. Zelený kanál je schopen zobrazit v nejlepším kontrastu pozadí s lézemi. Červený kanál má výhodu, že je světlejší, a rozkládá se v širší škále šedých barev, co má za následek menší kontrast mezi světlými lézemi a pozadím sítnice. Popsané nastavení pak nejlépe eliminuje ostrůvky, které mohou vznikat mezi okraji světlých lézí, a mohou být chybně označeny jako červená léze. Poté je nutné zvýšit kontrast snímku použitím *contrast stretching*. Následuje sjednocení intenzity v pozadí na celém obrázku užitím středního filtru.



Obrázek 21: (a) obrázek se zeleným kanálem, (b) snímek po spojení zeleného a červeného kanálu, (c) výsledný snímek po úpravě kontrastu a sjednocení intenzity

Profil šedé úrovně průřezu červené léze může být aproximován Gausovou tvarovou křivkou. Pro detekci červených lézí je použita detekce *matched filter detection*. Červené léze mají obvykle špatný lokální kontrast. Proto je navržen *two-dimensional matched filter kernel*, který zesílí červené léze na snímku.


Jeho prototyp je vyjádřen takto:

$$f(x, y) = -\exp\left(-\frac{x^2}{2\sigma^2}\right) \text{ pro } |y| \leq L/2 \quad (13)$$

Kde L je délka segmentu, pro který má céva předpoklad mít fixní orientaci. Sada dvanácti 16×15 pixelů velkých jader, je aplikována vinutím k fundus snímku, a v každém pixelu je zachováno jejich maximum citlivosti. Díky tomuto procesu je zvětšen kontrast krevních cév a také červených lézí. Pro řádnou extrakci segmentů červených lézí z *matched filter response* (MFR) obrázku, je nutné efektivní prahování. Prahovací algoritmus je založen na relativní entropii a zohledňuje prostorové rozložení šedých úrovní. Je užita protože některé MFR snímky mají komplikované vztahy mezi popředím a pozadím. Zvláště se pak implementuje lokální relativní entropiová prahová technika, která velmi dobře zachová strukturní detaily obrázku. Relativní entropické prahování slouží k minimalizování rozdílnosti.

Pro efektivní detekci kandidátních segmentů červených lézí na prahovaných snímcích je důležité potlačení krevních cév. Pro tento účel se využívá morfologická *top-hat* operace. Tato operace je založena na morfologickém otevření snímku s lineárními strukturními prvky v různých orientacích. Celkem dvanáct rotujících strukturních elementů je použito s radiálním rozlišením 15° . Následně je obrázek po *top-hat* transformaci odečten od prahovaného snímku, pro získání pouze kandidátních segmentů lézí. Protože se léze neobjevují na velkých cévách sítnice, jsou tyto cévy

odpojeny od snímku. K získání možných kandidátních oblastí se provádí *connected component analysis*. Všechny objekty, které jsou příliš velké na to, aby byly lézemi, jsou odstraněny. Byl nalezen práh 300 pixelů, který zahrnuje 98 % všech červených lézí. Většina vaskulatury je tvořena objekty většími než je 300 pixelů a mohou být tímto krokem odstraněny.



Obrázek 22: Zbylé objekty po connected component analysis

Klasifikace kandidátů červených lézí se provádí pomocí *support vector machines* SVM, což je statistická učební metoda založená na minimalizaci strukturálního rizika SRM. To může mapovat vstupní vektor x na vysoko-rozměrové rysy prostoru výběrem nelineárního mapovacího jádra. Optimální oddělovací nad-rovina v hlavním prostoru je dána vztahem:

$$f(x) = \text{sgn}\left[\sum_{i=1}^l y_i \alpha_i k(x_i, x) + b\right] \quad (14)$$

Kde y_i jsou, k je jádrová funkce, b je úhlopříčka a α_i jsou Langrovy násobiče. V tomto článku bylo použito lineární jádro a sjednocený parametr $c = 10$.




Obrázek 23: Kandidátní červené léze po SVM klasifikaci

Existuje několik systémů, které využívají binární SVM pro řešení problémů, jako je „jeden versus zbytek“ a „jeden versus jeden“. Cílem této práce je klasifikovat červené léze a falešné červené léze. K této klasifikaci je zapotřebí řádně zvolit příslušné funkce. Pro zlepšení výkonnosti této metody bylo zvoleno 12 dalších funkcí, vypočtených z výskytové matice. [10]

Tyto funkce zahrnují:

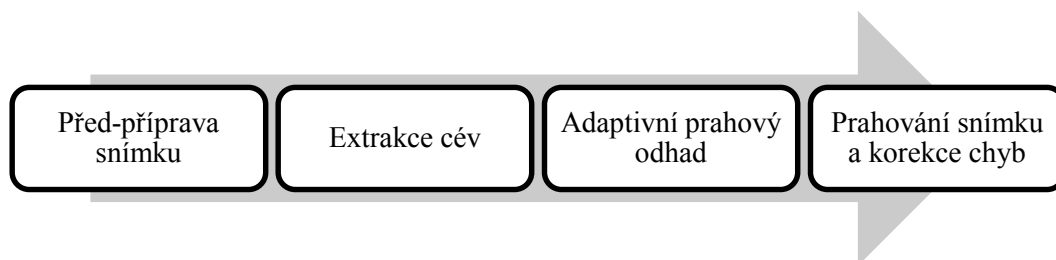
- 1) Úhlový moment setrvačnosti
- 2) Kontrast
- 3) Korelaci
- 4) Součet čtverců
- 5) Inverzní rozdílový moment
- 6) Součet průměru
- 7) Součet rozptylu
- 8) Součet entropie
- 9) Entropie
- 10) Rozdíl rozptylu
- 11) Rozdíl entropie
- 12) Měření informace pro korelaci



Obrázek 15: Snímky (a) a (c) zobrazují snímky sítnice v zeleném kanálu, (b) a (d) zobrazují výsledek detekce červených lézí


4.5 Detekce lézí metodou adaptivního prahování

Algoritmus probíhá ve čtyřech krocích.



Obrázek 24: Blokový diagram adaptivního algoritmu

Během předzpracování snímku dojde ke korekci odstínu pozadí. Korekce odstínu pozadí zajistí odstranění jakéhokoliv šumu na snímku. K tomuto se využívá *top-hat* transformace.



Obrázek 25: Obrázek (vlevo) před top-hat transformací a (vpravo) je po provedení top-hat transformace

K extrakci cév sítnice ze snímku dochází použitím matched filter, který je popsán rovnicí:


$$h = \frac{1}{\sqrt{s^H R_V^{-1} s}} R_V^{-1} s \quad (15)$$

kde R_V je hermetická symetrická matice, s^H je konjugovaná transpozice s , s je žádaný signál a v je aditivní šum.

Dále je použita Gaussova derivace:

$$f(x) = ae - \frac{(x-b)^2}{2c^2} \quad (16)$$


kde a , b , c , jsou konstanty.



Obrázek 26: Extrakce cév

Přestože MF využívá předchozí znalosti, že průřez cév na retinálním snímku je Gaussova tvaru, plně nevyužívá další informace o tvaru cév, zejména to, že Gaussův tvar průřezu je symetrický s ohledem na postavení jeho vrcholu. Použitím této vlastnosti je možné rozlišit symetrické struktury cév od asymetrických okrajů, které nepatří cévám. Toto je jednoduchá, ale efektivní cesta ke zlepšení přesnosti extrakce cév.

Adaptivní odhad prahu je zaveden z důvodu použití různých fundus kamer, kdy nastává rozdíl v kvalitě obrázku.




Obrázek 27: Dva fundus snímky s rozdílnou kvalitou

Velké rozdíly mohou být standardizovány jedním měřítkem barevného rytmu nebo intenzity. Tyto standardy ale mohou vést ke zvýšení šumu. Zajištění standardizace kvality snímku je také obtížný úkol, a proto byl stanoven požadavek, který vedl k tomuto adaptivnímu systému. Vzhledem k tomu, že červené léze jsou krevní sraženiny, a mají velmi podobnou barvu jako krevní cévy, je proto nutné předchozím krokem cévy eliminovat. Poté je vypočítán aritmetický průměr intenzity všech pixelů, detekovaných jako cévy. Vypočtený průměr je pak nastaven jako horní hranice prahu U . Empiricky je určeno okno intenzity úrovně $= 6$ ($U - L = 6$). Toto bylo zjištěno jako nejúčinnější k segmentaci červených lézí spolu s krevními cévami.

Prahování obrázku a korekce chyb je posledním krokem algoritmu. Užitím hodnot prahu z předchozího kroku jsou detekovány červené léze spolu s cévami, optickým nervem uvnitř optického disku a foveou. NAND logická operace se používá k odstranění detekovaných cév pomocí výstupního obrazu z procesu extrahování krevních cév. Pro odstranění optického disku a fovee ze snímku, se využívá známých skutečností, že optický disk je vždy kruhová jasná oblast a fovea je tmavá oblast s pevnou pozicí vzhledem k poloze optického disku. [11]


4.6 Detekce lézí pomocí dvou fází detekování kandidátních lézí

V první fázi dochází k předzpracování snímku a extrakci kandidátních lézí dvěma způsoby. V druhé fázi dochází k odstranění ne-červených lézí s různých míst.




Obrázek 28: Vývojový diagram první fáze zpracování snímku

Předzpracování snímku obnáší převod snímku na zelenou chrominační složku. Zelená chrominační složka zaručí nejlepší zřetelnost červených lézí. Dalším krokem je pak úprava na standardizovanou velikost 640 x 480 pixelů. Fundus snímky často dominují nestejnou intenzitou na pozadí. To zhoršuje kvalitu práce systému, který extrahuje kandidátní léze. Všechny pomalé gradienty na pozadí snímku zelené úrovně obrazu se odstraní, což vede k úpravě odstínu obrázku. Toto bylo provedeno odhadem pozadí obrázku a odečtením od zelené chrominační složky snímku. Pozadí obrázku je vytvořeno středovým filtrováním zelené plochy snímku s 25 x 25 pixelovým jádrem. Velikost středového filtru je zvolena tak, aby byla širší než je nejširší céva v jejích data setu snímku.




Obrázek 29: Snímek (vlevo) znázorňuje úpravu na zelený kanál, snímek (vpravo) je po sjednocení intenzity pozadí

Dále byl modifikován Spencer – Frame systém. Ten slouží k potlačení světlých lézí sítnice, které mohou být detekovány jako falešně pozitivní léze. K odstranění těchto světlých lézí dochází následujícím způsobem. Snímek po korekci pozadí má záporné hodnoty pixelů ve všech částech, které jsou tmavší, než je pozadí. Odstraněním všech pixelů dosahujících kladných hodnot z obrázku odstraníme světlé patologie, které nebudou mít vliv na pozdější analýzu snímku. Vybrané kladné pixely se nastaví na nulovou hodnotu.




Obrázek 30: Výsledek spencer - frame systému

Další částí je extrakce kandidátů založena na matematické morfologii. Tato metoda je převzata a detailně popsána v jiném článku. V tomto článku je pouze stručné objasnění principu. Pro rozlišení kruhových, nespojených červených lézí a dlouhých cév je použita top-hat transformace. Tato operace je založena na morfologickém otevření snímku s lineárním prvkem struktury v různých orientacích. Celkem 18 rotačních prvků struktury je užíváno s paprskovitým rozlišením 100. Délka prvků struktury by měla být větší než je největší červená léze přítomná v sadě. To bylo zkusmo stanoveno na délku 7 pixelů, který je nejlepším kompromisem mezi segmenty cév a červených lézí. V každém z 18 otevřených snímků, zůstanou pouze ty části cév, ve kterých se mohou uložit lineární prvky struktury. Užitím maximální hodnoty pixelů v každé pixelové lokaci v každém z 18 snímků, je získána mapa, kde jsou pouze cévy sítnice. Tato výsledná mapa je odečtena od snímku, kde byla provedena korekce pozadí. Výsledkem je snímek, obsahující zejména neprodloužené struktury jakou jsou červené léze.




Obrázek 31: Extrakce cév



Obrázek 32: Výsledný snímek po morfologické operaci


Následující částí je detekce kandidátních lézí binárním prahováním. Aby bylo možné odhalit neprodloužené struktury přesně, je zvýšen kontrast mezi pozadím a červenými lézemi. Za tímto účelem je použit přizpůsobený filtr. Je použit 2-D Gaussův filtr o velikosti $\sigma = 3$ pixely a s velikostí jádra 15×15 pixelů. Odpovídající filtr snímku obsahuje červené léze s ostrými okraji.



Obrázek 33: Snímek s vhodným filtrem s ostře ohraničenými lézemi

Následně je snímek po filtraci prahován na binární formu. Práh je upevněn v určité úrovni nad typickou hodnotou snímku. Zde je 0,2 násobek maximální hodnoty filtrovaného snímku použit jako prahová hodnota

V druhé fázi dochází k eliminaci falešně pozitivních lézí. K odstranění falešně pozitivních lézí je užitá tříkroková strategie.




Obrázek 34: Druhá fáze detekce červených lézí

První etapa je odstranění ne-červených lézí odkudkoliv. Falešně pozitivní léze identifikovány kdekoli na snímku se zobrazují jako tmavší textury, neboť napodobují texturu červených lézí. Ze studie vyplývá, že rozdíl mezi falešně pozitivní lézí a červenou lézí je, že červená léze se jeví tmavší než je okolní region sítnice, zatímco u falešně pozitivních je okolí velmi podobné. Většina falešně pozitivních lézí identifikována tímto systémem je z této kategorie. Z tohoto důvodu se očekávalo, že falešně pozitivní léze by mohly být odstraněny srovnáním kandidátních pixelů s hodnotami pixelů sousedních. Proto je vypočtena průměrná hodnota všech detekovaných kandidátů. Pokud je průměrná intenzita kandidáta nižší než hodnota sousedního pixelu pro určité množství, dotyčný kandidát bude považován za červenou lézi pro další eliminaci.

Další částí je odstranění nečervených částí, které jsou na cévách. V této kategorii se falešně pozitivní léze zobrazují tmavší a jejich počet je nižší. I přes to je třeba tyto falešně pozitivní léze odstranit. Jejich studie ukázala, že falešně pozitivní léze tohoto typu mají vysoký kontrast mezi pozadím (cévy), zatímco kontrast mezi červenými lézemi a pozadím je v tomto případě cév velmi nízká. Takže míra zbývajících kandidátů je vypočtena ze změny intenzity s ohledem na pozadí. Kandidáti, jejichž procentní změna v intenzitě byla nad určitou hodnotou, se vyřadí, a ostatní jsou zachovány jako červené léze.

Následující krok odstraní ne-červené léze z oblasti optického disku. V místě optického disku vystupuje mnoho cév, u kterých může dojít ke křížení jejich cest. Toto křížení může vytvořit malé oblasti, které mohou být označeny jako falešně pozitivní léze. K odstranění falešně pozitivních lézí z oblasti optického disku byla využita jejich předchozí práce extrakce optického disku. Zde je pro detekci očního disku použita maska a kandidáti spadající do oblasti této masky jsou odstraněni.


Výsledkem tohoto všeho je konečný snímek s detekovanými červenými lézemi.[12]



Obrázek 35: Na snímku (a) je zobrazen výčet všech falešně pozitivních lézí, snímek (b) je po redukci nečervených lézí odkudkoliv, snímek (c) znázorňuje léze po redukci falešně pozitivních lézí na cévách a snímek (d) je výsledný snímek po poslední redukci falešně pozitivních lézí z optického disku


5 ANALÝZA PACIENTSKÝCH DAT

Algoritmus pro detekci sítnicových lézí je testován na vzorku 120 reálných patientských obrazových záznamů. Jedná se o anonymní snímky sítnice dětí, pořízené kamerou RetCam 3, které poskytlo Centrum pro děti s vadami zraku Oční kliniky Fakultní nemocnice Ostrava. Rozlišení snímků je 640x480 pixelů, což je v dnešní době velice malé rozlišení. Kvalita snímku primárně závisí na lékaři a jeho práci s retinální kamerou. To je hlavní příčina rozdílné kvality snímků v námi dostupném datasetu. Rozdíly se týkají především jasových vlastností snímku a ostrosti.



Obrázek 36: Rozdílné retinální snímky

Běžně je na snímcích zachycen optický disk a cévní řečiště, ale mohou se zde také vyskytnout retinální léze, které jsou patologickým jevem na sítnici.



Obrázek 37: Snímek sítnice

Ze sady 120 snímků je pouze zúžená skupina dvou snímků, na kterých se nachází detekovatelné retinální léze. Za retinální léze považujeme krvácivé skvrny manifestující červenou barvou.




Obrázek 38: Snímek reprezentující zastoupení lézí

Detekci lézí komplikuje fakt, že jejich barevné spektrum je mnohdy identické s barevným spektrem cévního řečiště.

6 TEORETICKÝ NÁVRH ALGORITMU

Tato kapitola se věnuje návrhu a řešení algoritmu detekce retinálních lézí a extrakce jejich geometrických parametrů. Algoritmus se skládá z několika základních kroků, které znázorňuje blokové schéma.

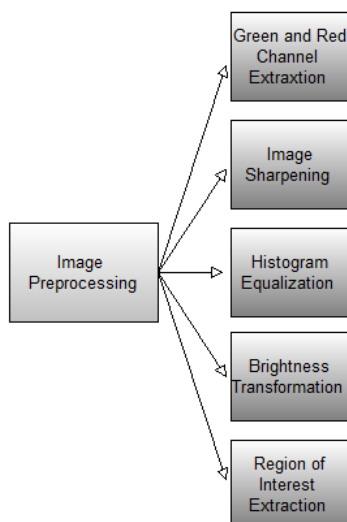


Obrázek 39: Blokové schéma jednotlivých kroků algoritmu

Inicializační částí navrženého algoritmu je digitální obrazový záznam pořízený retinální kamerou RetCam3. V prvním kroku je provedeno předzpracování snímku. Ve druhém kroku je aplikovaná segmentační metoda, která separuje červené léze od pozadí snímku. Finálním výstupem navrženého algoritmu je extrakce geometrických parametrů léze.

6.1 Předzpracování snímku

Prvním, a také velice důležitým krokem ve zpracování obrazu, je jeho předzpracování. Cílem předzpracování je dosažení co největšího zvýraznění retinálních lézí vůči pozadí. Vhodným předzpracováním snímku zvýšíme úspěšnost následujících kroků detekce lézí. V této fázi algoritmu dochází ke zlepšení kontrastních vlastností a zvýraznění hran objektu na snímku pomocí rozličných operací.



Obrázek 40: Blokové schéma jednotlivých kroků předzpracování obrazu

Předzpracování je provedeno těmito jednotlivými metodami:


- Výběr vhodného barevného kanálu
- Ostření obrazu
- Ekvalizace histogramu
- Jasové transformace
- Výběr zájmové oblasti (RoI)
- Binarizace

6.1.1 Výběr vhodné chrominační složky retinálních záznamů

Každý barevný RGB snímek je složen ze tří chrominačních vrstev – červená, zelená a modrá chrominační vrstva. Matematicky je RGB obraz reprezentován trojrozměrnou maticí, kterou můžeme rozložit na jednotlivé chrominační složky, které mají tvar 2D matice. Pro jednotlivé chrominační složky je charakteristické zviditelnění určitých částí (objektů) obrazu. Výběrem vhodné chrominační složky nebo jejich kombinací docílíme vytříbení požadovaných vlastností snímku, jako například zlepšení jasu, ostroty a zviditelnění objektů vůči pozadí snímku.




Obrázek 41: Barevný RGB snímek



Obrázek 42: Rozklad na jednotlivé chrominační složky

Vlastností jednotlivých chrominačních složek je v algoritmu využito pro zviditelnění lézí oproti očnímu pozadí a zlepšení výsledků následujících operací. Pro následující kroky zpracování obrazu byla aplikována kombinace červené a zelené chrominační složky, protože tato kombinace vykazovala nejlepší zvýraznění retinálních lézí a dostatečně prosvětlení tmavých okrajových oblastí snímku. Během procesu extrakce červené a zelené chrominační složky dochází k potlačení složky modré, což matematicky znamená vynulování prvků matice modré chrominační složky.



Obrázek 43: Červená a zelená chrominační složka



```

9 - model_RG(:, :, 1) = i(:, :, 1);
10 - model_RG(:, :, 2) = i(:, :, 2);
11 - model_RG(:, :, 3) = zeros(r, s);

```

Obrázek 44: Ukázka algoritmu pro extrakci červené a zelené chrominační vrstvy

Dále je provedena monochromatická úprava snímku pro lepší zviditelnění retinálních lézí. Monochromatizace znamená převedení obrazu z barevné RGB škály na šedotónovou škálu barev. [16][17]




Obrázek 45: Barevný snímek (vlevo), monochromatický snímek (vpravo)

6.1.2 Ostření obrazu

Následující operací na monochromatizovaném obrazu je ostření snímku a zvýraznění hran objektů. Ostřením obrazu a zvýrazněním hran zintenzivníme zřetelnost léze od pozadí. Ostrost obrazu a jeho objektů je ve skutečnosti rozdíl neboli přechod mezi různými barvami. Rychlý přechod z černé barvy na bílou, je registrován jako obraz ostrý. Pomalejší přechod je pak vnímán jako obraz rozmazaný. Principem ostření obrazu je zvýšení kontrastu podél hran, kde se setkávají různé barvy. Hranou je myšlena dostatečně strmá změna jasové stupnice v obraze. Zostření obrazu lze chápat jako zdůraznění vysokých frekvencí obrazu, protože neostrost a šum je zapříčiněná frekvencemi nízkými.

V algoritmu je pro ostření obrazu použita metoda „unsharp“ maskování. Tato technika je založena na možnosti odečtení rozostřené verze obrazu od originálu. Využívá faktu, že rozostřená verze snímku má vyšší obsah složek nižších frekvencí, než originál. Odečtením dochází k relativnímu snížení složek s nižší frekvencí a zvýraznění složek vyšších frekvencí, tedy hran. Samotný proces není na první pohled dobře znatelný, ovšem je důležitou částí pro následující kroky. [16][17][18]




Obrázek 46: Snímek neupravený (vlevo), snímek po aplikaci „unsharp“ maskování (vpravo)

6.1.3 Ekvalizace histogramu


Třetím krokem předzpracování obrazu je metoda ekvalizace histogramu. Ta se využívá pro zlepšení kontrastních vlastností snímků. Principem je změna rozložení jasových hodnot histogramu snímku. Provedením ekvalizace histogramu je zajištěno stejnoměrné rozložení jednotlivých úrovní jasu.

Histogram je jednoduchou, avšak důležitou komponentou snímku. Znázorňuje rozložení hodnot intenzity šedých úrovní všech pixelů snímku. Každá hodnota histogramu reprezentuje jednotlivé hodnoty intenzit zastoupených v obraze.




Obrázek 47: Snímek sítnice a jeho histogram

Pro docílení lepších kontrastních vlastností retinálních lézí byla využita metoda CLAHE. Je to metoda adaptivního histogramu ekvalizace (Contrast-Limited adaptive histogram equalization). Výhodou metody je provedení operace na malých oblastech snímku, oproti běžné ekvalizaci histogramu, která probíhá na celém snímku. Kontrast je zvýšen postupně na každé malé oblasti. Histogram je používán pro každou oblast individuálně. Sousední oblasti jsou následně spojeny bilineární interpolací, pro eliminace uměle vytvořené hranice. [16][17]



Obrázek 48: Nativní retinální data (vlevo), snímek po zvýšení kontrastu metodou CLAHE (vpravo)



Obrázek 49: Originální histogram snímku (vlevo), ekvalizace histogramu (vpravo)

6.1.4 Jasové transformace

Jasové transformace jsou využívány pro práci s hodnotami jasu. Existuje několik možností přístupu k jasovým transformacím. Podle velikosti vyšetřované oblasti rozlišujeme globální, lokální a bodové jasové transformace. Při globální jasové transformaci je nová hodnota pixelu vypočítaná vždy z hodnot na celém obrazu. U lokální jasové transformace dochází k výpočtu nové hodnoty z nejbližšího okolí pixelu. V navrženém algoritmu je použita metoda bodové jasové transformace. Jedná se o transformaci vstupní jasové hodnoty na hodnotu výstupní. Matematicky lze jasovou transformaci vyjádřit takto: $q = T(p)$.

Kde:

T-transformační funkce

p-vstupní hodnota jasu


q-nová (výstupní) hodnota jasu.

Jasové transformace slouží ke změně jasu obrazu tedy, korekci nestejnorodosti osvětlení. Touto metodou je ale také možné pracovat s kontrastem obrazu. V navrženém algoritmu je jasová transformace aplikována k zintenzivnění kontrastu, s úmyslem maximalizace zviditelnění retinálních lézí. Proces je proveden metodou bodové jasové transformace. U této metody je operace provedena pro každý pixel zvlášť. Výstupní hodnota je počítána ze vstupní hodnoty pouze jednoho pixelu. [16][17]


$$f'(x, y) \xrightarrow{T} (x, y) \forall x, y \in \Omega(I) \quad (17)$$

Kde:

$\Omega(I)$ vyznačuje doménu celého obrazu




Obrázek 50: Rozdělení jasových transformací



Obrázek 51: (Vlevo) je snímek před jasovou transformací, (vpravo) po provedení operace jasové transformace

6.1.5 Výběr zájmové oblasti (RoI)

Posledním krokem předzpracování obrazu je výběr zájmové oblasti v obraze (RoI – region of interest). Vzhledem k různé kvalitě a nestejnorodosti snímků nebylo možné algoritmus aplikovat na celý snímek, ale je nutno vybrat konkrétní oblast s přítomnou lézí. Proto se tento krok stal nezbytnou součástí navrženého algoritmu. K tomuto procesu je využito v MATLABu funkce `imcrop`. Funkci `imcrop` definuje RoI, kterým uživatel selektuje část obrazu, která je v popředí zájmu. Pomocí interaktivního kurzoru obdélníkového tvaru je uživatelem vybrána zájmová oblast s přítomnou lézí a následně snímek je ořezán podle uživatelem vybrané oblasti. I přes možnost velice přesného ohraničení lézí mohou být v ohraničení přítomny také cévy sítnice. Vzhledem k téměř totožné intenzitě barvy a odstínu není možné tyto cévy na snímku potlačit. [16][17][18]



Obrázek 52: Původní upravený snímek s označenou vybranou oblastí léze



Obrázek 53: RoI s retinální lézí

6.2 Segmentace obrazu

Kapitola segmentace obrazu se věnuje druhému bloku navrženého algoritmu a principu použité metody. Proces segmentace je aplikován na předzpracovaný snímek a slouží k oddělení zájmových pixelů od pixelů pozadí. Při segmentaci je využíváno rozdílných intenzit barev jednotlivých objektů retinálního snímku k separaci zájmových pixelů, tedy pixelů retinálních lézí. Zde byla aplikována operace binarizace metodou prahování.[17]

6.2.1 Binarizace snímku

Principem binarizace je rozdělení pixelů snímku na dvě skupiny a nastavení hodnot intenzity jasů pixelů na hodnoty 1 a 0. Zvolením prahu T , jsou pixely snímku F rozřazeny do dvou skupin t_i a t_j , podle jejich hodnot jas. Pixely snímku f s hodnotou intenzity vyšší než je zvolený práh T jsou zařazeny do skupiny t_i , opačně pixely nabývající hodnot intenzity nižších než je práh T , jsou zařazeny do skupiny t_j . Poté byly hodnoty pixelů ve skupině t_i nastaveny na hodnotu 1, tedy černá barva, pixely druhé skupiny t_j byly vynulovány, tedy jsou reprezentovány barvou bílou.

$$t_i \geq T$$

$$t_j < T$$

$$[T(f)] = \begin{cases} 1 & \text{pokud } = t_i \\ 0 & \text{pokud } = t_j \end{cases}$$



Obrázek 54: RoI oblast (vlevo), RoI s lézí po binarizaci (vpravo)

6.3 Extrakce geometrických parametrů

Posledním krokem navrženého algoritmu je extrakce geometrických parametrů retinálních lézí. Tato kapitola je zaměřena na princip extrakce geometrických parametrů retinálních lézí. Zde je uvažován výpočet plochy a průměru retinální léze. Algoritmus je proveden pomocí matematických operací. Je nutné podotknout, že vzdálenost změřená na obrazovém záznamu, neodpovídá reálné vzdálenosti, kterou by bylo možné naměřit přímo na sítnici. Vzhledem k absenci geometrických parametrů nativních snímků, bylo ustanoveno, že veškeré výsledky extrakce geometrických parametrů budou uváděny v obrazové jednotce pixel.

Výpočet geometrických parametrů probíhá na segmentovaném snímku. Léze je na tomto výřezu reprezentována černou barvou, kdežto okolí je zastoupeno barvou bílou. Nejprve je zjištěna celková velikost segmentovaného snímku. Tento krok je realizován pomocí zjištění počtu řádků a sloupců 2D matice, která reprezentuje segmentovaný snímek. V druhé části jsou postupně pomocí cyklické operace kontrolovány všechny pixely snímku. Jsou hledány veškeré pixely zastoupeny černou barvou, tedy pixely, nabývající hodnoty 0. Jestliže algoritmus narazí na pixel, jehož hodnota je 0, zapíše jej jako člen vektoru *pl*. Po prozkoumání celé matice snímku je výsledná plocha léze vypočítaná pomocí součtu všech zapsaných členů vektoru *pl*. Výsledkem je hodnota reprezentující počet pixelů retinální léze.

```

4 - [r s]=size(i);
5 - l=1;
6 - for ii=1:r
7 -     for jj=1:s
8 -         if i(ii,jj)==0
9 -             pl(l)=i(ii,jj);
10 -            l=l+1;
11 -         end
12 -     end
13 - end
14
15 - plocha_leze=length(pl)

```

Obrázek 55: Ukázka kódu cyklické operace algoritmu v MATLABu

I přes skutečnost, že léze nejsou přesnou kružnicí, ale jejímu tvaru se velice blíží, počítáme jejich průměr. Pomocí běžných matematických vztahů pro výpočet plochy a průměru kružnice je algoritmem stanoven průměr léze v pixelech.

$$S = \pi \cdot r^2 \quad (18)$$

$$r = \sqrt{\frac{S}{\pi}} \quad (19)$$

S – plocha optického disku v pixelech

r – poloměr optického disku v pixelech

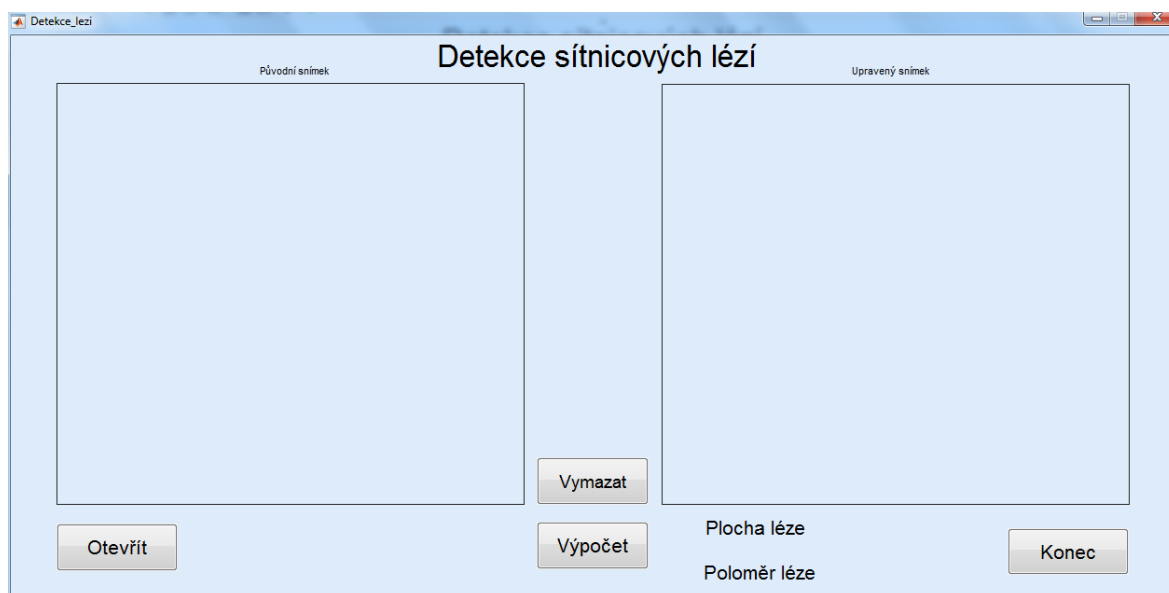
```
144 - | r=round((sqrt(plocha_leze/pi)));
```

Obrázek 56: Ukázka kódu v MATLABu pro výpočet poloměru léze

7 GRAFICKO-UŽIVATELSKÉ ROZHRAŇÍ


Finálním krokem práce je realizace příjemného graficko-uživatelského prostředí pro analýzu geometrických parametrů retinálních lézí. K tomuto bylo využito možnosti tvorby prostředí přímo v programu MATLAB. Tato kapitola se zabývá vývojem graficko-uživatelského rozhraní pro detekci sítnicových lézí a extrakce jejich geometrických parametrů. Účelem aplikace je zjednodušení a zpříjemnění práce se sítnicovými snímky. Do software byly zaimplementovány veškeré popsané použité metody. To umožňuje uživateli pomocí jednoduchých operací využívat zdrojový kód algoritmu bez nutnosti jeho znalosti.

Po spuštění navrženého softwaru se otevře uživatelské okno pro následující práci s retinálními snímky. Okno obsahuje dva prostory pro zobrazení retinálních snímků, a to okno pro původní snímek, a okno pro upravený snímek. Dále rozhraní zahrnuje čtveřici ovládacích prvků ve formě tlačítek. V pravé spodní části jsou oblasti pro zobrazení výsledku poloměru a plochy léze v jednotkách pixelech.



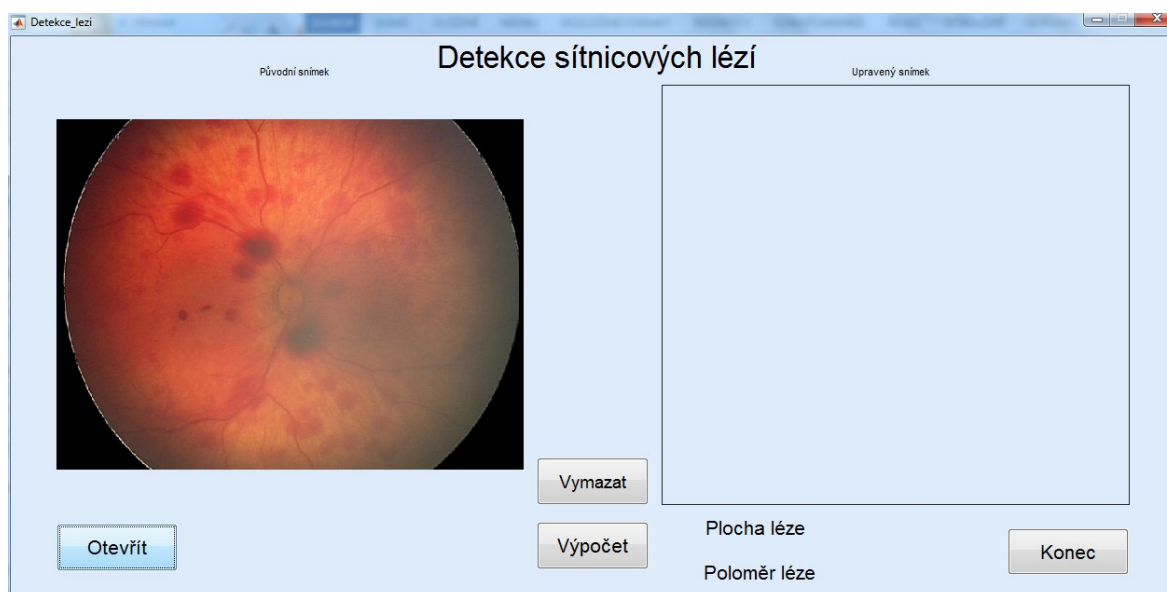
Obrázek 57: Vzhled graficko-uživatelského rozhraní po spuštění

V prvním kroku je řešena funkce výběru požadovaného snímku pomocí průzkumníku v počítači. Stisknutím ovládacího prvku otevřít je vyvoláno a uživateli zobrazeno dialogové okno, ve kterém je vyhledán požadovaný retinální snímek na úložišti v počítači, a následně je načten do uživatelského rozhraní. Primárně jsou v dialogovém okně pro výběr retinálního snímku zobrazeny snímky ve formátu .jpg, ovšem je možné, pomocí rolovací lišty v pravém dolním rohu okna, měnit formát zobrazovaných snímků.



Obrázek 58: Proces načtení snímku do uživatelské aplikace


Po načtení obrázku je snímek vykreslen v levém panelu pro původní snímky. I po načtení má uživatel možnost změnit výběr snímku, pokud došlo k omylu při výběru, a to opětovným stisknutím ovládacího prvku otevřít, nebo jej úplně vymazat pomocí ovládacího prvku vymazat.



Obrázek 59: Načtený vybraný snímek

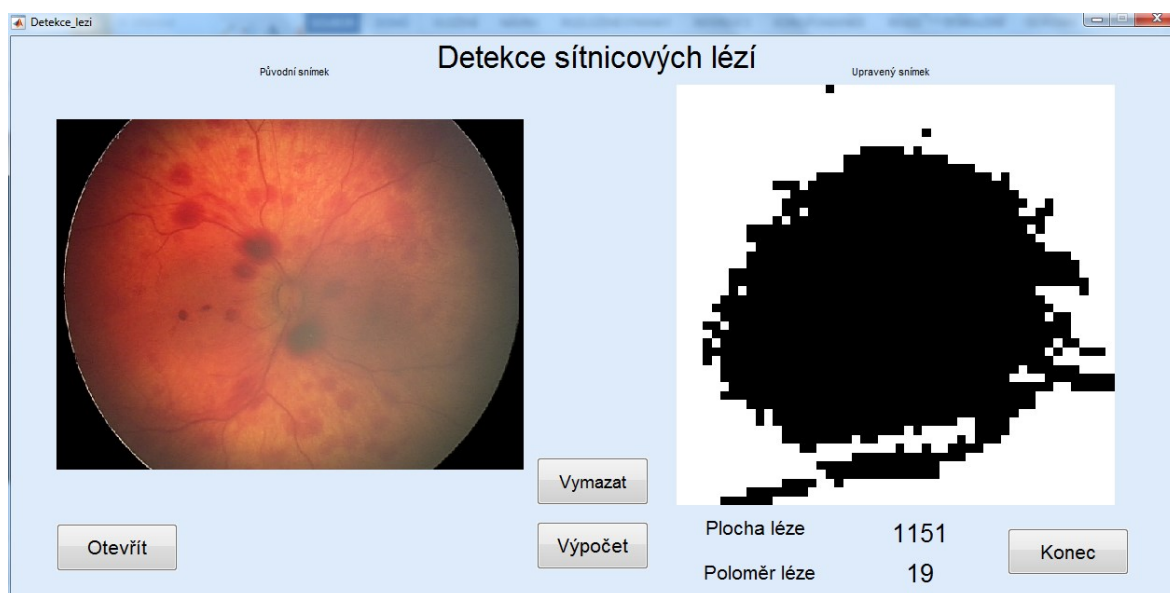
Úpravy načteného nativního retinálního snímku jsou řízeny ovládacím prvkem „vypočítat“. Stisknutím ovládacího prvku vypočítat, jsou zahájeny operace předzpracování. Upravený předzpracovaný retinální snímek se načte do pravého okna pro snímky. Následně program čeká na uživatelský výběr oblasti RoI s přítomnou retinální lézí. Výběr RoI s retinální lézí je řešen kurzorem, který tahem ohraničí libovolnou oblast na snímku. V našem případě se jedná o nejbližší okolí retinální léze. S vybranou oblastí je možné jakkoliv pohybovat jako s celkem, nebo libovolně měnit její velikost. Díky těmto vlastnostem je možné docílit přesnějšího ohraničení léze a částečně zabránit přítomnosti nechtěným objektům například cévám, nebo přítomnosti části léze sousední. V některých

případech není možné zabránit přítomnosti nechtěných objektů ve výřezu ani při velmi precizním ohraničení oblasti. Výběr je potvrzen dvojklikem kursoru myši na vybranou oblast s lézí. V levém okně zůstává původní nativní snímek, který zůstane vyobrazen během všech následujících operací.



Obrázek 60: Předzpracovaný snímek s vybranou oblastí přítomné léze


Po výběru prostoru s přítomnou lézí pomocí kursoru a oříznutí snímku se v pravém okně vykreslí oblast binarizované retinální léze. Následují početní operace algoritmu, které proběhly v pozadí, bez uživatelského zásahu, počítají plochu a poloměr léze. Výsledky matematických operací jsou zviditelněny pod segmentovaným snímek v pravé dolní polovině uživatelského rozhraní.



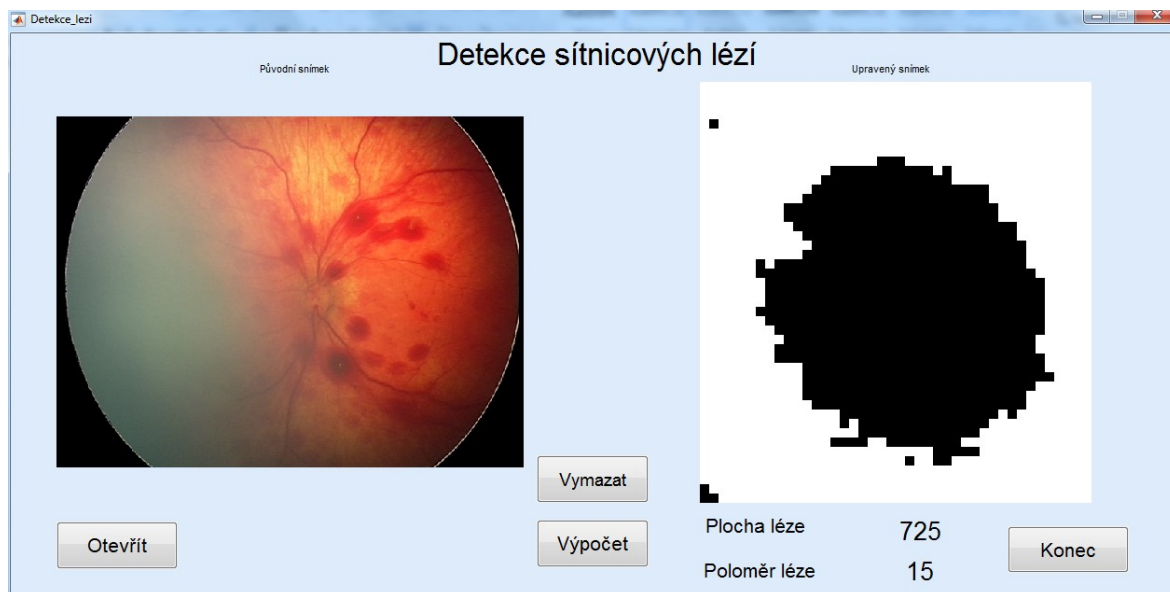
Obrázek 61: Výsledky poloměru a plochy léze

Nyní má uživatel dvě možnosti pokračování, a to vymazání obou panelů s vykreslenými snímky a vynulování výsledků výpočtu plochy a průměru léze prvkem vymazat. Po vymazání může uživatel znova načíst nový snímek stejným postupem jako prvně. Dále může uživatel ukončit aplikaci ovládacím prvkem „konec“. Také se může vrátit na výběr RoI léze stejného načteného

snímku pomocí ovládacího prvku výpočet. Program opět vykreslí předzpracovaný snímek do levého panelu a vyčká na uživatelský výběr RoI.



Obrázek 62: Další příklad detekování léze v GUI




Obrázek 63: Výsledná detekovaná léze

8 TESTOVÁNÍ ALGORITMU NA REÁLNÝCH PACIENTSKÝCH DATECH


Poslední částí bakalářské práce je testování navrženého algoritmu na reálných patientských datech. V této kapitole je řešeno otestování celé uživatelské aplikace, v níž je naimplementován navržený algoritmus. Vzhledem k omezenému počtu snímku s přítomnými retinálními lézemi proběhlo testování pouze na dvou snímcích.

Vzhledově jsou snímky podobné, ovšem jejich kvalita je rozdílná. Pravý snímek je mírně zašedlý jako celek, ale léze jsou zřetelné téměř na celém snímku. Levý snímek je z poloviny zakryt neprůhlednou šedou oblastí, kterou nelze žádnou úpravou potlačit. Pravá polovina levého snímku je o poznání kontrastnější oproti snímku pravému.



Obrázek 64: Testované snímky


V prvním kroku předzpracování obrazu dojde k extrakci červené a zelené chrominační vrstvy a převedení obrazu z barevného na monochromatický. V tomto kroku nedochází k řízenému zvyšování kontrastu, ale je využito vlastností jednotlivých chrominačních složek ke zvýraznění retinálních lézí.



Obrázek 65: Monochromatické snímky s extrahovanou červenou a zelenou chromatickou složkou


Ve druhém kroku předzpracování je provedeno ostření obrazu metodou „unsharp“. Na první pohled jsou změny takřka nerozpoznatelné, proces je ovšem nezbytný pro zkvalitnění následujících kroků. Zde dochází ke zvýraznění hran objektů snímku, tedy retinálních lézí, cév a optického disku.

Léze po tomto kroku nejsou dostatečně zvýrazněny, zůstávají téměř nezměněny, jsou málo kontrastní, a proto je nutné použít další metody.




Obrázek 66: Snímky po provedení „usharp“ operace

Třetí nezbytnou součástí je provedení adaptivní ekvalizace histogramu. Po této operaci je viditelné zlepšení kontrastních vlastností obou snímků. Léze se projevují tmavší barvou, jsou také daleko zřetelnější cévy sítnice, pozadí nabývá světlejšího odstínu šedé. Došlo k razantnímu potlačení zašedlé oblasti na levém snímku a zviditelnění hůře zřetelných objektů, které byly původně překryty šedou částí. Na pravém obrázku je zmenšena neprůhledná oblast na pravé polovině snímku.




Obrázek 67: Snímky po ekvalizaci histogramu

Předposledním krokem předzpracování je zvýšení kontrastu pomocí jasové transformace. Tato metoda se jeví jako velice účinná. Dochází ke znatelnému zintenzivnění barevného spektra lézí a jejich výraznému zviditelnění oproti pozadí a prosvětlení okolí. Tento proces je velice důležitý pro úspěšnou segmentaci, tedy separaci zájmových pixelů léze, kde je důležité, aby léze nabývala co nejtmavšího odstínu šedé, ideálně černé barvy.




Obrázek 68: Snímky po jasové transformaci

Ve finální části předzpracování je nutné provést výběr léze pomocí kursoru. Tahem kursoru je vybrána požadovaná oblast RoI. Po vybrání RoI s přítomnou lézí je provedena binarizace vybrané oblasti. Následující snímky prezentují výsledky detekování jednotlivých lézí. Jak je možné vidět na šestici snímcích, léze mají různorodou charakteristiku jak v jejich umístění tak i ve tvaru. Jsou přítomny léze, které leží odděleně, a jsou snadněji ohraničitelné. Na druhou stranu na retinálním snímku je možné nalézt léze, které leží na cévě sítnice, nebo v její těsné blízkosti.




Obrázek 69: Výsledky detekce lézí prvního testovaného snímku

Druhý testovaný snímek nedominoje tak tmavými lézemi jako testovaný snímek první, nicméně algoritmus je schopný detekovat i tyto méně kontrastní léze.



Obrázek 70: Výsledné detekce lézí druhého testovaného snímku


Na obrázku 71 můžeme vidět jednu z přesněji detekovatelných lézí. Léze je dobře ohraničená a na výřezu RoI se nenachází žádné další objekty, jako jsou především cévy nebo sousední léze. Výsledek plochy a poloměru léze není v tomto případě zkreslen nežádoucími objekty.



Obrázek 71: Detailnější zobrazení detekované léze a RoI

Vzhledem k tomu, že poloha retinálních lézí na sítnici není vždy tak ideální jako u předchozího příkladu, kdy se léze nacházela samostatně, dochází u některých snímků ke zkreslení

výsledku o připočtení pixelů nežádoucích objektů, jako jsou cévy nebo sousední léze. Na obrázku č. 72 je zachycená retinální léze, u které není možné provést výřez pouze samotné léze, ale v rámci RoI dochází k binarizaci také cévy a léze nacházející se v těsné blízkosti. Výsledná plocha retinální léze a její poloměr je pak zakreslen o pixely sousední léze a cévy.




Obrázek 72: Detekovaná léze

8.1 Výsledky testování

Na výše přiložených snímcích je testován algoritmus pro detekci retinálních lézí a extrakci jejich geometrických parametrů na reálných patientských datech. Testování proběhlo na dvou snímcích pro rozmanitou škálu lézí o různorodé velikosti, tvaru, kontrastu a pozici na sítnici.

Výsledky poloměru a plochy léze primárně závisí na umístění léze a přítomnosti nežádoucích objektů, jako jsou cévy sítnice a přilehlé léze nacházející se v těsné blízkosti. Pokud se v RoI nachází nechtěné objekty o téměř totožném nebo naprosto stejném odstínu barvy, dochází k nechtěnému připočítání pixelů nežádoucích částí k pixelům léze. Výsledná plocha a poloměr nabývá zkreslených hodnot. Věrohodnost výsledků je také podmíněná přesným ohraničením retinální léze.


Dále byl proveden výpočet a srovnání velikosti plochy léze vzhledem k velikosti plochy optického disku. Výsledky jsou prezentovány v přiložené tabulce. V této části bylo využito bakalářské práce, která se zabývá vývojem algoritmu pro automatizovanou detekci optického disku. Bylo zapotřebí spojení výsledků detekce plochy optického disku (OD) a poloměru OD, aby bylo možné provést srovnání velikosti léze vzhledem k velikosti optického disku. Velikost plochy a poloměru je uváděna v pixelech, výsledná hodnota poměru je uváděna v procentech.



Obrázek 73: Testované léze pro výpočty varianta 1.

Tabulka 3: Výsledky pro testovaný vzorový snímek varianta 1.

Č. léze	Plocha léze	Poloměr léze	% Plochy OD	Plocha OD
1.	503	13	44	1139
2.	1139	19	100	
3.	1915	25	168	
4.	1752	24	154	
5.	739	15	65	
6.	254	9	22	



Obrázek 74: Testované léze pro výpočty variantu 2.

Tabulka 4: Tabulka výsledků pro variantu snímku 2.

Č. léze	Plocha léze	Poloměr léze	% Plochy OD	Plocha OD
1.	1977	25	194	1018
2.	723	15	71	
3.	1908	25	187	
4.	757	16	74	
5.	916	17	90	
6.	546	13	54	

Z výsledků plyne, že na dostupných patientských obrazových datech se nachází celkem 6 testovaných lézí, které zabírají méně než 100% plochy optického disku. Pětice testovaných lézí zabírá svou plochou více než 100 % plochy optického disku a jedna testovaná léze má plochu totožnou jako je plocha optického disku.

ZÁVĚR

Vzhledem k tomu, že počty předčasně narozených dětí mají tendenci růstu, je včasná diagnostika onemocnění retinopatie nedonošených důležitým krokem k zabránění oslepnutí dítěte. Pro správnou diagnostiku je nutné, aby lékař měl možnost co nejdetailnějšího vědomí o stavu nezralé dětské sítnice. Proto je nutné docílit co nejlepšího zviditelnění patologií na retinálních snímcích sítnice oproti snímkům původním. Hlavním benefitem bakalářské práce je extrakce geometrických informací retinálních lézí a jejich následná kalkulace vzhledem k velikosti optického nervu. Tímto způsobem je možné výsledky vyšetření objektivizovat, neboť tato funkcionalita poskytuje zpětnou vazbu v podobě relace geometrických parametrů retinálních lézí vůči optickému nervu. Řešení této problematiky bylo zadáním mé bakalářské práce.

Výsledkem této bakalářské práce je algoritmus pro detekci sítnicových lézí naimplementovaný do graficko-uživatelského rozhraní pro práci s medicínskými obrazovými daty sítnice. Graficko-uživatelské prostředí je sestaveno tak, aby bylo snadné jej ovládat a bylo uživatelsky příjemné. Hlavní funkcí uživatelského rozhraní je vizualizace, úprava medicínských snímků a vyobrazení výsledků detekce retinálních lézí. Aby bylo možné toto provést, byl navržen a realizován algoritmus, který zajišťuje provedení požadovaných úprav snímků a výpočet geometrických parametrů lézí. Algoritmus byl vytvářen a přizpůsobován na základě poznatků a požadavků pro získání co nejlepších výsledků.

Vzhledem k nízkému rozlišení snímků a jejich rozdílné kvalitě nebylo možné algoritmus aplikovat na celou oblast snímku, ale bylo nutné přistoupit na manuální výběr RoI uživatelem. Je nutné také zmínit, že výsledky poloměru a plochy léze mohou být zkreslené o přítomnost nežádáných objektů jako jsou cévy sítnice a přilehlé léze, kterým se není možné při výběru RoI vyhnout. Zkreslení výsledku poloměru a plochy je způsobeno značnou podobností barevných spekter retinálních lézí a cév sítnice.

Návrh a tvorba graficko-uživatelského rozhraní a taktéž implementace algoritmu, bylo provedeno v software MATLAB R2016b.

SEZNAM POUŽITÉ LITERATURY

- [1] KUCHYŇKA, Pavel. Oční lékařství. Praha: Grada Publishing, a.s., 2007. ISBN 978-80-247-11638. [cit. 2015-09-10]
- [2] NAŇKA, Ondřej, Miloslava ELIŠKOVÁ a Oldřich ELIŠKA. *Přehled anatomie*. 2., dopl. a přeprac. vyd. Praha: Galén, c2009, xi, s. 311 - 318. ISBN 978-80-7262-612-0. [cit. 2015-08-15]
- [3] Dětské oční lékařství: Retinopatie nedonošených [online]. [cit. 2016-04-13]. Dostupné z: <http://telemedicina.med.muni.cz/pdm/detske-ocni-lekarstvi/index.php?pg=retinopatie-nedonoseny>
- [4] ŠENKOVÁ, Kateřina. Léčba a screening retinopatie nedonošených (ROP). Brno, 2010. Disertační práce. [cit. 2015-09-08] Dostupné z: https://is.muni.cz/th/29511/lf_d/phd.pdf
- [5] KRAUS, Hanuš. *Kompendium očního lékařství*. Vyd. 1. Praha: Grada, 1997. ISBN 80-716-9079-1.
- [6] CLARITY MEDICAL SYSTEMS, *RETCAM 3 – Pediatric eye imaging*. 2014. Pleasanton CA USA [online] [cit. 2015-07-08] Dostupné z: http://www.claritymsi.com/international/downloads/RC3Brochure_2013.pdf
- [7] HUAN WANG,, WYNNE HSU, KHENG GUAN GOH a MONG LI LEE. An effective approach to detect lesions in color retinal images. *Proceedings IEEE Conference on Computer Vision and Pattern Recognition. CVPR 2000 (Cat. No.PR00662)*. IEEE Comput. Soc, 2000, : 181-186. DOI: 10.1109/CVPR.2000.854775. ISBN 0-7695-0662-3. ISSN 1063-6919.
- [8] JAAFAR, H. F., A. K. NANDI a W. AL-NUAIMY. Automated detection of red lesions from digital colour fundus photographs. *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2011, : 6232-6235. DOI: 10.1109/IEMBS.2011.6091539. ISBN 978-1-4577-1589-1
- [9] KANDE, Giri Babu, T. Satya SAVITHRI, P. Venkata SUBBAIAH a M. R. M. TAGORE. Detection of red lesions in digital fundus images. In: *2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro* [online]. 2009 [cit. 2015-06-30]. DOI: 10.1109/isbi.2009.5193108.
- [10] USHER, D., M. DUMSKYJ, M. HIMAGA, T. H. WILLIAMSON, S. NUSSEY a J. BOYCE. Automated detection of diabetic retinopathy in digital retinal images: a tool for diabetic retinopathy screening. *Diabetic Medicine* [online]. 2004, **21**(1): 84-90 [cit. 2015-06-28]. DOI: 10.1046/j.1464-5491.2003.01085.x.
- [11] GANGULY, Shaunak, Shaumik GANGULY, Kshitij SRIVASTAVA, Malay Kishore DUTTA, M. PARTHASARATHI, Radim BURGET a Kamil RIHA. An adaptive threshold based algorithm for detection of red lesions of diabetic retinopathy in a fundus image. In: *2014 International Conference on Medical Imaging, m-Health and Emerging Communication Systems (MedCom)* [online]. 2014 [cit. 2015-07-01]. DOI: 10.1109/medcom.2014.7005982.
- [12] SHARATH KUMAR, P N, R RAJESH KUMAR, Anuja SATHAR a V SAHASRANAMAM. Automatic detection of red lesions in digital color retinal images. *2014 International Conference on Contemporary Computing and Informatics (IC3I)*. IEEE, 2014, : 1148-1153. DOI: 10.1109/IC3I.2014.7019607. ISBN 978-1-4799-6629-5.
- [131] Stavba oka. Encyklopedie fyziky [online]. Praha: Jaroslav Reichl and Martin Všeticka, 2006, 2015 [cit. 2015-11-12]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/486-stavba-oka>
- [14] Skolajecna.cz: biologie [online]. [cit. 2016-04-13]. Dostupné z: <http://skolajecna.cz/biologie/Images/Textbook/Big/0110000/00287.jpg>

- [15] *Sasilik: retinopathy of prematurity* [online]. [cit. 2016-04-13]. Dostupné z: <http://www.sasilik.com.tr/en/makaleler/9-retinopathy-of-prematurity->
- [16] GONZALEZ, Rafael C, Richard E WOODS a Steven L EDDINS. *Digital Image processing using MATLAB*. 2nd ed. S.l.: Gatesmark Publishing, c2009. ISBN 978-0-9820854-0-0.
- [17] KUBÍČEK, Jan. *Zpracování medicínských obrazových dat*. Vysoká škola báňská - Technická univerzita Ostrava, 2013. [cit. 2016-03-15].
- [18] HÁJOVSKÝ, Radovan, Radka PUSTKOVÁ a František KUTÁLEK. *Zpracování obrazu v měřicí a řídicí technice*. Vyd. 1. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2012. [online]
[cit. 2016-03-15]. ISBN 978-80-248-2596-0. Dostupné z:
<http://www.person.vsb.cz/archivcd/FEI/ZOMRT/Zpracovani%20obrazu%20v%20merici%20a%20ridici%20technice.pdf>
- [19] *Cmi: Medical technology* [online]. [cit. 2016-04-18]. Dostupné z: <http://www.cmi.sk/oftalmologie/diagnostika-1/zobrazovaci-systemy/digitalni-ofthalmoskopy/neprimy-ofthalmoskop-omega-200>
- [20] *IMsystems* [online]. [cit. 2016-04-18]. Dostupné z: <http://intelmed.ru/catalog/oft/oftalmodiagnostika/pediatricheskie-retinalnye-kamery/retcam3/>

SEZNAM PŘÍLOH

Příloha I. Obsah CD

Příloha I Obsah CD

- Bakalářská práce
- Graficko-uživatelské rozhraní
- Algoritmus pro detekci sítnicových lézí